arXiv:0904.4148v1 [math-ph] 27 Apr 2009

Approche variationnelle pour le calcul bayésien dans les problèmes inverses en imagerie

Ali Mohammad-Djafari

Laboratoire des signaux et systèmes

(UMR 08506, CNRS-SUPELEC-Univ Paris Sud)

Supélec, Plateau de Moulon, 91192 Gif-sur-Yvette Cedex, France

27 avril 2009

Résumé

Dans une approche bayésienne non supervisée pour la résolution d'un problème inverse, on cherche à estimer conjointement la grandeur d'intérêt $\boldsymbol{f}$ et les paramètres $\boldsymbol{\theta}$ à partir des données observées $\boldsymbol{g}$ et un modèle $\mathcal{M}$ liant ces grandeurs. Ceci se fait en utilisant la loi *a posteriori* conjointe $p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})$. L'expression de cette loi est souvent complexe et son exploration et le calcul des estimateurs bayésiens nécessitent soit les outils d'optimisation de critères ou de calcul d'espérances des lois multivariées. Dans tous ces cas, il y a souvent besoin de faire des approximations. L'approximation de Laplace et les méthodes d'échantillonnage MCMC sont deux approches classiques (analytique et numérique) qui ont été explorés avec succès pour ce fin. Ici, nous étudions l'approximation de $p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g})$ par une loi séparable en $\boldsymbol{f}$ et en $\boldsymbol{\theta}$. Ceci permet de proposer des algorithmes itératifs plus abordables en coût de calcul, surtout, lorsqu'on choisit ces lois approchantes dans des familles des lois exponentielles conjuguées. Le principal objet de ce papier est de présenter les différents algorithmes que l'on obtient pour différents choix de ces familles. À titre d'illustration, nous considérons le cas de la restauration d'image par déconvolution simple ou myope avec des *a priori* séparables, markoviens simples ou avec des champs cachés.

Variational Approche for Bayesien Computation for Inverse Problems in Imaging Systems

Ali Mohammad-Djafari

Laboratoire des signaux et systèmes

(UMR 08506, CNRS-SUPELEC-Univ Paris Sud)

Supélec, Plateau de Moulon, 91192 Gif-sur-Yvette Cedex, France

27 avril 2009

Abstract

In a non supervised Bayesian estimation approach for inverse problems in imaging systems, one tries to estimate jointly the unknown image pixels $\boldsymbol{f}$ and the hyperparameters $\boldsymbol{\theta}$ given the observed data $\boldsymbol{g}$ and a model $\mathcal{M}$ linking these quantities. This is, in general, done through the joint posterior law $p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})$. The expression of this joint law is often very complex and its exploration through sampling and computation of the point estimators such as MAP and posterior means need either optimization of or integration of multivariate probability laws. In any of these cases, we need to do approximations. Laplace approximation and sampling by MCMC are two approximation methods, respectively analytical and numerical, which have been used before with success for this task. In this paper, we explore the possibility of approximating this joint law by a separable one in $\boldsymbol{f}$ and in $\boldsymbol{\theta}$. This gives the possibility of developing iterative algorithms with more reasonable computational cost, in particular, if the approximating laws are choosed in the exponential conjugate families. The main objective of this paper is to give details of different algorithms we obtain with different choices of these families. To illustrate more in detail this approach, we consider the case of image restoration by simple or myopic deconvolution with separable, simple markovian or hidden markovian models.

1 Introduction

Une présentation simplifiée et synthétique des problèmes inverses en imagerie, en se plaçant en dimensions finies, consiste à vouloir retrouver une grandeur inconnue $\boldsymbol{f}$ à partir des observations $\boldsymbol{g}$ d'une grandeur observée, en supposant connaître un modèle $\mathcal{M}$ qui les lient. La forme la plus simple de ce modèle est un modèle linéaire de la forme

$$\mathcal{M}: \qquad \boldsymbol{g} = \boldsymbol{H}\boldsymbol{f} + \boldsymbol{\epsilon} \tag{1}$$

où on suppose que toutes les erreurs de modélisation et de mesure peuvent être représentées par $\boldsymbol{\epsilon}$. Notons aussi que $\boldsymbol{g}$ et $\boldsymbol{f}$ sont, en général, des vecteurs de grandes dimensions, ce qui signifie que nous considérons ici le cas discrétisé où $\boldsymbol{g}$ contient l'ensemble des grandeurs mesurées et $\boldsymbol{f}$ l'ensemble des valeurs qui décrivent la grandeur inconnue. Dans ce contexte $\boldsymbol{H}$ est une matrice dont les éléments sont définies par le modèle et les étapes de discrétisation du problème.

Dans une approche estimation bayésienne non supervisée pour résoudre un problème inverse, d'abord on utilise ce modèle pour définir la loi de probabilité $p(\boldsymbol{g}|\boldsymbol{f}, \boldsymbol{\theta}_1; \mathcal{M})$ où $\boldsymbol{\theta}_1$ représente l'ensemble des paramètres qui décrivent cette loi. Lors que cette fonction est considérée comme une fonction de $\boldsymbol{f}$ et de $\boldsymbol{\theta}_1$, elle est appelée la vraisemblance des inconnues $\boldsymbol{f}$ et $\boldsymbol{\theta}$ du modèle $\mathcal{M}$. Son expression s'obtient à partir de la loi de probabilité des erreurs $\boldsymbol{\epsilon}$ en utilisant le modèle (1). Par exemple, lorsque $\boldsymbol{\epsilon}$ dans ce modèle est modélisé par un vecteur aléatoire centré, blanc, gaussien et de covariance fixée $\boldsymbol{\Sigma}_\epsilon = {\sigma_\epsilon}^2 \boldsymbol{I}$, on a

$$p(\boldsymbol{g}|\boldsymbol{f}, \boldsymbol{\theta}_1; \mathcal{M}) = \mathcal{N}(\boldsymbol{H}\boldsymbol{f}, \boldsymbol{\Sigma}_\epsilon) \tag{2}$$

où $\boldsymbol{\theta}_1 = {\sigma_\epsilon}^2$. D'autres lois avec d'autres paramètres $\boldsymbol{\theta}_1$ peuvent bien sûr être utilisées.

La deuxième étape dans cette approche est l'attribution ou le choix d'une loi dite *a priori* $p(\boldsymbol{f}|\boldsymbol{\theta}_2; \mathcal{M})$ pour les inconnues $\boldsymbol{f}$, où $\boldsymbol{\theta}_2$ représente ses paramètres. La troisième étape consiste à écrire l'expression de la loi *a posteriori* des inconnues $\boldsymbol{f}$:

$$p(\boldsymbol{f}|\boldsymbol{\theta}, \boldsymbol{g}; \mathcal{M}) = \frac{p(\boldsymbol{g}, \boldsymbol{f}|\boldsymbol{\theta}; \mathcal{M})}{p(\boldsymbol{g}|\boldsymbol{\theta}; \mathcal{M})} = \frac{p(\boldsymbol{g}|\boldsymbol{f}, \boldsymbol{\theta}_1; \mathcal{M})\, p(\boldsymbol{f}|\boldsymbol{\theta}_2; \mathcal{M})}{p(\boldsymbol{g}|\boldsymbol{\theta}; \mathcal{M})}, \tag{3}$$

où on suppose implicitement connaître l'ensemble des paramètres $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2)$. Mais, dans un cas réel, nous sommes amenés souvent à les estimer aussi. Pour cela, dans l'approche bayésienne, on leur attribue aussi une loi *a priori* $p(\boldsymbol{\theta}|\mathcal{M})$, et l'on obtient alors une loi *a*

posteriori conjointe des inconnues $\boldsymbol{f}$ et des hyperparamètres $\boldsymbol{\theta} = (\boldsymbol{\theta}_1, \boldsymbol{\theta}_2)$:

$$\begin{aligned} p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M}) &= \frac{p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M})}{p(\boldsymbol{g}|\mathcal{M})} \\ &= \frac{p(\boldsymbol{g}|\boldsymbol{f}, \boldsymbol{\theta}_1; \mathcal{M})\, p(\boldsymbol{f}|\boldsymbol{\theta}_2; \mathcal{M})\, p(\boldsymbol{\theta}|\mathcal{M})}{p(\boldsymbol{g}|\mathcal{M})}. \end{aligned} \tag{4}$$

Dans cette relation, le dénominateur

$$p(\boldsymbol{g}|\mathcal{M}) = \iint p(\boldsymbol{g}|\boldsymbol{f}, \boldsymbol{\theta}; \mathcal{M})\, p(\boldsymbol{f}|\boldsymbol{\theta}; \mathcal{M})\, p(\boldsymbol{\theta}|\mathcal{M})\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta} \tag{5}$$

est la vraisemblance marginale du modèle $\mathcal{M}$ dont son logarithme $\ln p(\boldsymbol{g}|\mathcal{M})$ est appellé *évidence du modèle* $\mathcal{M}$.

Afin d'introduire les notions qui vont être utilisées dans la suite de ce travail, il est intéressant de mentionner que, pour n'importe quelle loi de probabilité $q(\boldsymbol{f}, \boldsymbol{\theta})$ (dont nous verrons le choix et l'utilité par la suite), l'évidence du modèle $\ln p(\boldsymbol{g}|\mathcal{M})$ vérifie

$$\begin{aligned} \ln p(\boldsymbol{g}|\mathcal{M}) &= \ln \iint p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M})\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta} \\ &= \ln \iint q(\boldsymbol{f}, \boldsymbol{\theta}) \frac{p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M})}{q(\boldsymbol{f}, \boldsymbol{\theta})}\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta} \\ &\geq \iint q(\boldsymbol{f}, \boldsymbol{\theta}) \ln \frac{p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M})}{q(\boldsymbol{f}, \boldsymbol{\theta})}\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta}. \end{aligned} \tag{6}$$

(d'après l'inégalité de Jensen : $\ln(\mathrm{E}\{p/q\}) \geq \mathrm{E}\{\ln(p/q)\}$). Aussi, notant par

$$\mathcal{F}(q) = \iint q(\boldsymbol{f}, \boldsymbol{\theta}) \ln \frac{p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M})}{q(\boldsymbol{f}, \boldsymbol{\theta})}\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta} \tag{7}$$

et par

$$\mathrm{KL}(q : p) = \iint q(\boldsymbol{f}, \boldsymbol{\theta}) \ln \frac{q(\boldsymbol{f}, \boldsymbol{\theta})}{p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})}\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta} \tag{8}$$

on montre facilement (en remplaçant $p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M}) = p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})\, p(\boldsymbol{g}|\mathcal{M})$ dans l'expression de $\mathcal{F}(q)$) que

$$\ln p(\boldsymbol{g}|\mathcal{M}) = \mathcal{F}(q) + \mathrm{KL}(q : p). \tag{9}$$

Ainsi $\mathcal{F}(q)$, appelée l'énergie libre de $q(\boldsymbol{f}, \boldsymbol{\theta})$ par rapport à $p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}|\mathcal{M})$, est une limite inférieure de $\ln p(\boldsymbol{g}|\mathcal{M})$ car $\mathrm{KL}(q : p) \geq 0$. Par la suite, nous allons écrire l'expression de $\mathcal{F}(q)$ par

$$\mathcal{F}(q) = \langle \ln p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}; \mathcal{M}) \rangle_q + \mathcal{H}(q) \tag{10}$$

où nous avons utilisé la notation $< \, . \, >_q$ pour l'espérance suivant la loi q et $\mathcal{H}(q)$ est l'entropie de q :

$$H(q) = -\iint q(\boldsymbol{f}, \boldsymbol{\theta}) \ln q(\boldsymbol{f}, \boldsymbol{\theta})\, \mathrm{d}\boldsymbol{f}\, \mathrm{d}\boldsymbol{\theta} \tag{11}$$

Arrivé à ce stade, les questions posées sont :

- **Inférence :** Étant donnée les expressions des lois *a posteriori* (3) et (4), comment les utiliser pour définir une solution au problème inverse décrit en (1) ?
- **Sélection de modèle :** Comment peut-on sélectionner un modèle parmi un ensemble de modèles $\mathcal{M}_i$.

En ce qui concerne le problème de l'inférence, les principaux choix sont les estimateurs au sens du Maximum *a posteriori* (MAP) ou au sens de la moyenne *a posteriori* (PM). Dans le premier cas, on a besoin des outils d'optimisation et dans le deuxième cas des outils d'intégration (analytique ou numérique). Pour la sélection du modèle, nous nous contenterons ici de noter que l'expression de la vraisemblance du moèle (5) peut être utilisés à cette fin. Dans ce papier, nous nous focalisons sur la première question où on cherche à inférer $\boldsymbol{f}$ et $\boldsymbol{\theta}$ utilisant la loi *a posteriori* jointe (4).

Pour les problèmes inverses, la solution au sens du MAP a été utilisée avec succès pour sa simplicité et en raison de son lien avec l'approche déterministe de la régularisation. Mais, il y a des situations où cette solution ne donne pas satisfaction, et où la solution au sens de la moyenne *a posteriori* peut être préférée. Mais, les situations où on peut avoir une solution analytique pour les intégrations qui sont nécessaires pour obtenir ces estimées sont rares. Il y a alors pratiquement deux voies :

Intégration numérique par échantillonnage : Il s'agit d'approcher les espérances par des moyennes empiriques des échantillons générés suivant la loi *a posteriori* . Toute la difficulté est alors de générer ces échantillons, et c'est là qu'interviennent les méthodes de MCMC (Markov Chain Monté Carlo). Le principal intérêt de ces méthodes est qu'elles permettent d'explorer l'ensemble de l'espace de la loi *a posteriori* , mais l'inconvénient majeur est leur coût de calcul qui est dû au nombre important d'itérations nécessaire pour la convergence des chaînes et le nombre important de points qu'il faut générer pour obtenir des estimations de bonnes qualités.

Approximation de la loi *a posteriori* par des lois plus simples : Il s'agit de reporter le calcul des intégrales après une simplification par approximation de la loi *a posteriori* . Une première approximation utilisée historiquement est *Approximation de Laplace* où on approxime la lois *a posteriori* par une loi gaussienne. Dans ce cas, les deux

estimateurs MAP et PM sont équivalents et tous les calculs deviennent analytiques.

Une deuxième solution est d'approcher la *a posteriori* par une loi séparable, ce qui permet de réduire la dimension des intégrations. Cette voie est plus récente et le principal objet de ce papier.

De façon générale, l'idée d'approcher une loi conjointe $p(\boldsymbol{x})$ de plusieurs variables $\boldsymbol{x}$ par une loi séparable $q(\boldsymbol{x}) = \prod_j q_j(x_j)$ n'est pas nouveau et peut être trouvée dans la littératures de la fin des années 90 : [1, 2, 3, 4, 5, 6, 7]. Le choix d'un critère pour mesurer la qualité de cette approximation et l'étude des effets de cette approximation sur les qualités des estimateurs obtenus apparaît dans les travaux plus récents [8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19]. L'usage de cette approche en estimation des paramètres d'un modèle d'observation avec des variables cachées en statistique est également récente [20, 19, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35]. Dans la plupart de ces travaux, l'application est plutôt en classification en utilisant un modèle de mélanges. Dans le domaine du traitement du signal, ils utilisent des modèles de mélange avec des étiquettes des classes modélisées par des chaînes de Markov. Dans le domaine du traitement d'image, la plupart de ces travaux sont consacrés à la segmentation d'image en utilisant soit un modèle séparable ou markovien pour les étiquettes. Cette approche a été aussi utilisé récemment en séparation de sources [36, 37, 38] et en traitement des images hyperspectrales [39, 40]. L'application réelle de cette approche pour simplifier les calculs bayésiens dans les problèmes inverses avec un opérateur mélangeant est l'originalité de ce travail [41, 42, 43]. En effet, dans la plupart de ces travaux, avec les notations utilisées dans ce papier, on suppose qu'on a observé directement $\boldsymbol{f}$ dont la loi est modélisée par un mélange de gaussiennes et le principal objectif de ces méthodes est l'estimation des paramètres de ce mélange et la sélection du modèle. Dans d'autres travaux on considère un modèle d'observation ponctuel où $g_i = h(f_i) + \epsilon_i$ et l'objective est la segmentation de l'image $\boldsymbol{f}$. Les travaux dans lesquels, on utilise l'approche variationnelle pour des problèmes inverses de restauration ou de reconstruction d'images sont assez rare. On trouve essentiellement les travaux [44, 45, 46] qui considèrent le cas des problèmes inverses linéaires, mais soit avec des modèles *a priori* de Gauss-Markov ou avec des variables cachées de contours ou d'étiquettes des régions séparables. La dépendance spatiale de ces variables cachées n'est pas prise en compte.

La suite de ce papier est organisée de la manière suivante : une présentation très synthétique de l'approche variationnelle est fournie dans la section 2. Dans la section 3, nous nous intéresserons à l'approximation de la loi *a posteriori* $p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})$ pour les problèmes inverses. Il s'agit alors d'appliquer l'approche variationnelle pour ce cas particulier avec différent choix pour les familles des lois approchantes. Dans la section 4, nous détaillerons l'application de la méthode au cas de la restauration simple ou myope d'image. Enfin, dans la section 5, nous décrirons la manière d'appliquer cette méthode au cas de la restauration d'image avec une modélisation *a priori* plus complexe : un modèle hiérarchique de Gauss-Markov avec un champ caché de Potts pour des étiquettes des régions dans l'image. En effet, cette modélisation convient pour bien des cas de restauration et de reconstruction d'images dans des applications où l'image recherchée représente un objet composé d'un nombre fini de matériaux homogènes. C'est exactement cette information *a priori* qui est modélisée par un modèle de mélange avec des étiquettes $\boldsymbol{z}$ markoviennes [47]. Ici, donc, la loi *a posteriori* $p(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})$ doit être approximée par des lois plus simples à utiliser. Finalement, dans la section 6, nous résumons les apports de ce papier. Il est à noter cependant, que dans ce papier, seules les principes des méthodes proposées sont présentés et les détails de mise en oeuvre de ces méthodes, ainsi que des résultats de simulations et évaluation des performances de ces algorithmes sont reportées à un prochaine papier.

2 Principe de l'approche variationnelle

Considérons le problème général de l'approximation d'une loi conjointe $p(\boldsymbol{x}|\mathcal{M})$ de plusieurs variables $\boldsymbol{x}$ par une loi séparable $q(\boldsymbol{x}) = \prod_j q_j(x_j)$. videment, il faut choisir un critère. Considérons le critère de divergence $\mathrm{KL}(q : p)$ entre p et q :

$$\mathrm{KL}(q : p) = \int q(\boldsymbol{x}) \ln \frac{q(\boldsymbol{x})}{p(\boldsymbol{x}|\mathcal{M})} \, \mathrm{d}\boldsymbol{x}$$

et cherchons la solution $\widehat{q}(\boldsymbol{x})$ qui le minimise. La solution optimale ne peut être calculée que d'une manière itérative, car ce critère n'étant pas quadratique en q, sa dérivée par rapport à q n'est pas linéaire et une solution explicite n'est pas disponible. On peut alors envisager une solution itérative coordonnée par coordonnée.

Notons $q_{-j}(\boldsymbol{x}_{-j}) = \prod_{i \neq j} q_i(x_i)$, ce qui permet d'écrire $q(\boldsymbol{x}) = q_j(x_j)\, q_{-j}(\boldsymbol{x}_{-j})$ où $\boldsymbol{x}_{-j} =$

$\{x_i, i \neq j\}$ et dévéloppons ce critère :

$$\begin{aligned}
\mathrm{KL}(q:p) &= -\int q(\boldsymbol{x}) \ln \frac{p(\boldsymbol{x}|\mathcal{M})}{q(\boldsymbol{x})} \, \mathrm{d}\boldsymbol{x} \\
&= -H(q) - \langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q(\boldsymbol{x})} \\
&= -\sum_j H(q_j) - \langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q(\boldsymbol{x})} \\
&= -\sum_j H(q_j) - \int \langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q_{-j}} \, q_j(x_j) \, \mathrm{d}x_j
\end{aligned} \tag{12}$$

où $H(q)$ est l'entropie de q et $H(q_j)$ est l'entropie de q_j.

Notons que si q_{-j} est fixée $\mathrm{KL}(q:p)$ est convexe en q_j et sa minimisation sous la contrainte de normalisation de q_j s'écrit

$$q_j(x_j) = \frac{1}{C_j} \exp\left[\langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q_{-j}}\right] \tag{13}$$

avec

$$C_j = \int \exp\left[\langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q_{-j}}\right] \, \mathrm{d}x_j \tag{14}$$

On note que l'expression de q_j dépend de celle de q_{-j} et que, l'obtention de q_j (étant donnée q_{-j}) se fait aussi d'une manière itérative en deux étapes :

$$\begin{cases} \mathcal{Q}(q_j) &= H(q_j) + \langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q_j)} \, , \\ q_j^{(k+1)} &= \arg\max_{q_j} \{\mathcal{Q}(q_j)\} \, , \end{cases} \tag{15}$$

ce qui ressemble à un algorithme du type EM (Espérance-Maximisation) généralisé, car dans la première équation nous avons à calculer une espérance et dans la deuxième étape nous avons une maximisation.

Les calculs non paramétriques sont souvent trop coûteux. On choisit alors une forme paramétrique pour ces lois de telle sorte que l'on puisse, à chaque itération, remettre à jour seulement les paramètres de ces lois, à condition cependant que ces formes ne changent pas au cours des itérations. La famille des lois exponentielles conjuguées ont cette propriété [2, 44, 48, 49, 50, 51, 30].

La première étape de simplification de ce calcul est donc de considérer la famille des lois paramétriques $q_j(x_j|\boldsymbol{\theta}_j)$ où $\boldsymbol{\theta}_j$ est un vecteur de paramètres. En effet, dans ce cas, l'algorithme itératif précédent se transforme à :

$$\begin{cases} \mathcal{Q}(\boldsymbol{\theta}_j) &= H\left(q_j(x_j|\boldsymbol{\theta}_j)\right) + \langle \ln p(\boldsymbol{x}|\mathcal{M}) \rangle_{q_j(x_j|\boldsymbol{\theta}_j)} \, , \\ \boldsymbol{\theta}_j^{(k+1)} &= \arg\max_{\boldsymbol{\theta}_j} \{\mathcal{Q}(\boldsymbol{\theta}_j)\} \, , \end{cases} \tag{16}$$

ce qui ressemble plus à un algorithme du type EM.

Une deuxième étape de simplification est de choisir pour $p(\boldsymbol{x}|\boldsymbol{\theta};\mathcal{M})$ la famille des lois exponentielles conjuguées :

$$p(\boldsymbol{x}|\boldsymbol{\theta};\mathcal{M}) = f(\boldsymbol{x})\, g(\boldsymbol{\theta})\, \exp\left[\boldsymbol{\phi}(\boldsymbol{\theta})^T \boldsymbol{u}(\boldsymbol{x})\right] \tag{17}$$

où $\boldsymbol{\phi}(\boldsymbol{\theta})$ est le vecteur de paramètres naturel et $f(\boldsymbol{x})$, $g(\boldsymbol{\theta})$ et $\boldsymbol{u}(\boldsymbol{x})$ sont des fonctions connues. Il est alors facile de montrer que $q_j(x_j)$ dans l'équation (13) sera aussi dans la famille des lois exponentielles conjuguées, et par conséquence $q(\boldsymbol{x}|\widetilde{\boldsymbol{\theta}})$ restera dans la même famille et nous aurons juste à remettre à jours ses paramètres.

Remarque : Cette famille de lois a une propriété dite *conjuguée* dans le sens que si on choisit comme *a priori*

$$p(\boldsymbol{\theta}|\eta,\boldsymbol{\nu}) = h(\eta,\boldsymbol{\nu})\, g(\boldsymbol{\theta})^{\eta}\, \exp\left[\boldsymbol{\nu}^T \boldsymbol{\phi}(\boldsymbol{\theta})\right] \tag{18}$$

l'*a posteriori* correspondant

$$p(\boldsymbol{\theta}|\boldsymbol{x};\mathcal{M}) \propto p(\boldsymbol{x}|\boldsymbol{\theta};\mathcal{M})\; p(\boldsymbol{\theta}|\eta,\boldsymbol{\nu}) \tag{19}$$

sera aussi dans la même famille (18). La famille des lois *a priori* (17) est alors dites *conjuguée* de la famille des lois (16).

Pour cette famille de lois, on a

$$\langle \ln p(\boldsymbol{x}|\boldsymbol{\theta};\mathcal{M})\rangle_q = \langle \ln f(\boldsymbol{x})\rangle_q + \ln g(\boldsymbol{\theta}) + \boldsymbol{\phi}(\boldsymbol{\theta})^T \langle \boldsymbol{u}(\boldsymbol{x})\rangle_q \tag{20}$$

et donc la forme de la loi séparable q_j correspondante est

$$q_j(x_j|\widetilde{\boldsymbol{\theta}}) \propto g(\widetilde{\boldsymbol{\theta}}) \exp\left[< f(\boldsymbol{x}) >_{q_j} + \boldsymbol{\phi}(\widetilde{\boldsymbol{\theta}})^T < \boldsymbol{u}(\boldsymbol{x}) >_{q_j}\right] \tag{21}$$

où $\widetilde{\boldsymbol{\theta}}$ désigne les paramètres particuliers de q_j qu'il faut mettre à jour au cours des itérations.

Par ailleurs, sachant que $q(\boldsymbol{x})$ est séparable, si $\ln p(\boldsymbol{x}|\boldsymbol{\theta};\mathcal{M})$ est polynomial en $\boldsymbol{x}$, le calcul de l'espérance (20), mais surtout celui de sa dérivée par rapport aux q_j et aux paramètres $\boldsymbol{\theta}$, qui sont nécessaire pour l'optimisation, seront facilités. Comme nous le verrons par la suite, pour les problèmes inverses, nous avons choisi ce genre de lois.

3 Approche variationnelle pour les problèmes inverses linéaires

Nous allons maintenant utiliser ces relations pour décrire le principe de l'approche variationnelle au cas particulier des problèmes inverses (1) où l'utilisation directe de la loi *a posteriori* conjointe $p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})$ dans l'équation (4) est souvent trop coûteuse pour pouvoir être explorée par échantillonnage direct de type Monté Carlo ou pour calculer les moyennes *a posteriori*

$$\widehat{\boldsymbol{f}} = \int \int \boldsymbol{f}\ p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})\ \mathrm{d}\boldsymbol{\theta}\ \mathrm{d}\boldsymbol{f} \tag{22}$$

et

$$\widehat{\boldsymbol{\theta}} = \int \int \boldsymbol{\theta}\ p(\boldsymbol{f}, \boldsymbol{\theta}|\boldsymbol{g}; \mathcal{M})\ \mathrm{d}\boldsymbol{f}\ \mathrm{d}\boldsymbol{\theta}. \tag{23}$$

En effet, rare sont les cas où on puisse trouver d'expressions analytiques pour ces intégrales. De même l'exploration de cette loi par des méthodes de Monté Carlo est aussi coûteuses. On cherche alors à l'approcher par une loi plus simple $q(\boldsymbol{f}, \boldsymbol{\theta})$. Par simplicité, nous entendons par exemple une loi q qui soit séparable en $\boldsymbol{f}$ et en $\boldsymbol{\theta}$:

$$q(\boldsymbol{f}, \boldsymbol{\theta}) = q_1(\boldsymbol{f})\ q_2(\boldsymbol{\theta}) \tag{24}$$

videmment, cette approximation doit être faite de telle sorte qu'une mesure de distance entre q et p soit minimale. Si, d'une manière naturelle, on choisi $\mathrm{KL}(q : p)$ comme cette mesure, on aura :

$$(\widehat{q}_1, \widehat{q}_2) = \arg \min_{(q_1, q_2)} \{\mathrm{KL}(q_1 q_2 : p)\} = \arg \max_{(q_1, q_2)} \{\mathcal{F}(q_1 q_2)\} \tag{25}$$

et sachant que $\mathrm{KL}(q_1 q_2 : p)$ est convexe en q_1 à q_2 fixée et vice versa, on peut obtenir la solution d'une manière itérative :

$$\left\{ \begin{array}{ll} \widehat{q}_1 & = \arg\min_{q_1} \{\mathrm{KL}(q_1 \widehat{q}_2 : p)\} = \arg\max_{q_1} \{\mathcal{F}(q_1 \widehat{q}_2)\}\,; \\ \widehat{q}_2 & = \arg\min_{q_2} \{\mathrm{KL}(\widehat{q}_1 q_2 : p)\} = \arg\max_{q_2} \{\mathcal{F}(\widehat{q}_1 q_2)\}\,. \end{array} \right. \tag{26}$$

Utilisant la relation (7), il est facile de montrer que les solutions d'optimisation de ces étapes sont

$$\left\{ \begin{array}{ll} \widehat{q}_1(\boldsymbol{f}) & \propto \exp\left[\langle \ln p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}; \mathcal{M})\rangle_{\widehat{q}_2(\boldsymbol{\theta})}\right] \\ \widehat{q}_2(\boldsymbol{\theta}) & \propto \exp\left[\langle \ln p(\boldsymbol{g}, \boldsymbol{f}, \boldsymbol{\theta}; \mathcal{M})\rangle_{\widehat{q}_1(\boldsymbol{f})}\right] \end{array} \right. \tag{27}$$

Une fois cet algorithme convergé vers $\widehat{q}_1^*(\boldsymbol{f})$ et $\widehat{q}_2^*(\boldsymbol{\theta})$, on peut les utiliser d'une manière indépendante pour calculer, par exemple les moyennes $\widehat{\boldsymbol{f}}^* = \int \boldsymbol{f}\ \widehat{q}_1^*(\boldsymbol{f})\ \mathrm{d}\boldsymbol{f}$ et $\widehat{\boldsymbol{\theta}}^* = \int \boldsymbol{\theta}\ \ \widehat{q}_2^*(\boldsymbol{\theta})\ \mathrm{d}\boldsymbol{\theta}$.

Comme nous l'avons déjà indiqué, les calculs non paramétriques sont souvent trop coûteux. On choisit alors une forme paramétrique pour ces lois de telle sorte que l'on puisse, à chaque itération, remettre à jour seulement les paramètres de ces lois. Nous examinons ici, trois cas :

3.1 Cas dégénéré

On prend pour $q_1(\boldsymbol{f})$ et $q_2(\boldsymbol{\theta})$ des formes dégénérées suivantes :

$$\left\{\begin{array}{ll} q_1(\boldsymbol{f}|\widetilde{\boldsymbol{f}}) & = \delta(\boldsymbol{f}-\widetilde{\boldsymbol{f}}) \\ q_2(\boldsymbol{\theta}|\widetilde{\boldsymbol{\theta}}) & = \delta(\boldsymbol{\theta}-\widetilde{\boldsymbol{\theta}}) \end{array}\right. \tag{28}$$

Par conséquence, au cours des itérations, nous n'aurons qu'à remettre à jour $\widetilde{\boldsymbol{f}}$ et $\widetilde{\boldsymbol{\theta}}$. En remplaçant $q_1(\boldsymbol{f})$ et $q_2(\boldsymbol{\theta})$ dans les relations (27) on obtient :

$$\left\{\begin{array}{l} \widehat{q}_1(\boldsymbol{f}) \propto p(\boldsymbol{g},\boldsymbol{f},\widetilde{\boldsymbol{\theta}};\mathcal{M}) \propto p(\boldsymbol{f},\widetilde{\boldsymbol{\theta}}|\boldsymbol{g};\mathcal{M}) \\ \widehat{q}_2(\boldsymbol{\theta}) \propto p(\boldsymbol{g},\widetilde{\boldsymbol{f}},\boldsymbol{\theta};\mathcal{M}) \propto p(\widetilde{\boldsymbol{f}},\boldsymbol{\theta}|\boldsymbol{g};\mathcal{M}). \end{array}\right. \tag{29}$$

Il est alors facile de voir que la recherche de $\widetilde{\boldsymbol{f}}$ et $\widetilde{\boldsymbol{\theta}}$ au cours des itérations devient équivalent à :

$$\left\{\begin{array}{l} \widetilde{\boldsymbol{f}} = \arg\max_{\boldsymbol{f}} \left\{p(\boldsymbol{g},\boldsymbol{f},\widetilde{\boldsymbol{\theta}};\mathcal{M})\right\} = \arg\max_{\boldsymbol{f}} \left\{p(\boldsymbol{f},\widetilde{\boldsymbol{\theta}}|\boldsymbol{g};\mathcal{M})\right\} \\ \widetilde{\boldsymbol{\theta}} = \arg\max_{\boldsymbol{\theta}} \left\{p(\boldsymbol{g},\widetilde{\boldsymbol{f}},\boldsymbol{\theta};\mathcal{M})\right\} = \arg\max_{\boldsymbol{\theta}} \left\{p(\widetilde{\boldsymbol{f}},\boldsymbol{\theta}|\boldsymbol{g};\mathcal{M})\right\} \end{array}\right. \tag{30}$$

On remarque alors que l'on retrouve un algorithme de type MAP joint ou ICM (Iterated Conditional Mode). L'inconvénient majeur ici est qu'avec le choix (28), les incertitudes liées à chacune des inconnues $\boldsymbol{f}$ et $\boldsymbol{\theta}$ ne sont pas prise en compte pour l'estimation de l'autre inconnue.

3.2 Cas particulier conduisant à l'algorithme EM

On prend comme dans le cas précédent une forme dégénérée pour $q_2(\boldsymbol{\theta}) = \delta(\boldsymbol{\theta}-\widetilde{\boldsymbol{\theta}})$, ce qui donne

$$\widehat{q}_1(\boldsymbol{f}) \propto p(\boldsymbol{g},\boldsymbol{f},\widetilde{\boldsymbol{\theta}};\mathcal{M}) \propto p(\boldsymbol{f},\widetilde{\boldsymbol{\theta}}|\boldsymbol{g};\mathcal{M}) \propto p(\boldsymbol{f}|\widetilde{\boldsymbol{\theta}},\boldsymbol{g};\mathcal{M}) \tag{31}$$

ce qui signifie que $\widehat{q}_1(\boldsymbol{f})$ est une loi dans la même famille que la loi *a posteriori* $p(\boldsymbol{f}|\boldsymbol{\theta},\boldsymbol{g};\mathcal{M})$. Évidemment, si la forme de cette loi est simple, par exemple une gaussienne, (ce qui est le cas dans les situations que nous étudierons) les calculs seront simples.

A chaque itération, on aurait alors à remettre à jour $\widetilde{\boldsymbol{\theta}}$ qui est ensuite utilisé pour trouver $\widehat{q}_1(\boldsymbol{f}|\widetilde{\boldsymbol{\theta}}) = p(\boldsymbol{f}|\widetilde{\boldsymbol{\theta}},\boldsymbol{g};\mathcal{M})$, elle même utilisée pour calculer

$$Q(\boldsymbol{\theta},\widetilde{\boldsymbol{\theta}}) = \langle \ln p(\boldsymbol{g},\boldsymbol{f},\boldsymbol{\theta};\mathcal{M})\rangle_{\widehat{q}_1(\boldsymbol{f}|\widetilde{\boldsymbol{\theta}})}\,. \tag{32}$$

On remarque facilement l'équivalence avec l'algorithme EM qui se résume à :

$$\begin{cases} \text{E}: \;\; Q(\boldsymbol{\theta},\widetilde{\boldsymbol{\theta}}) = \langle \ln p(\boldsymbol{g},\boldsymbol{f},\boldsymbol{\theta};\mathcal{M})\rangle_{\widehat{q}_1(\boldsymbol{f}|\widetilde{\boldsymbol{\theta}})}\,, \\ \text{M}: \;\; \widetilde{\boldsymbol{\theta}} \qquad = \arg\max_{\boldsymbol{\theta}} \left\{ Q(\boldsymbol{\theta},\widetilde{\boldsymbol{\theta}}) \right\}. \end{cases} \tag{33}$$

L'inconvénient majeur ici est que l'incertitude liée à $\boldsymbol{\theta}$ n'est pas prise en compte pour l'estimation de $\boldsymbol{f}$.

3.3 Choix particulier proposé pour les problèmes inverses linéaires

Il s'agit de choisir, pour $q_1(\boldsymbol{f})$ et $q_2(\boldsymbol{\theta})$ des lois dans les mêmes familles de lois que celles de $p(\boldsymbol{f}|\boldsymbol{g},\boldsymbol{\theta})$ et de $p(\boldsymbol{\theta}|\boldsymbol{g},\boldsymbol{f})$. En effet, comme nous le verrons plus bas, dans le cas des problèmes inverses linéaires (1) avec des choix approprié pour les lois *a priori* associée à la modélisation directe du problème, ces lois *a posteriori* conditionnelles restes dans les mêmes familles, ce qui permet de profiter de la mise à jour facile de ces loi.

Dans ce travail, dans un premier temps, nous allons considéré le cas des problèmes inverses linéaires (1) : $\boldsymbol{g} = \boldsymbol{H}\ \boldsymbol{f} + \boldsymbol{\epsilon}$, où $\boldsymbol{H}$ représente la forme discrétisé de la modélisation directe du problème et $\boldsymbol{\epsilon}$ représente l'ensemble des erreurs de mesure et de modélisation avec des hypothèses suivantes :

$$\begin{aligned} p(\boldsymbol{g}|\boldsymbol{H},\boldsymbol{f},\theta_e;\mathcal{M}) &= \mathcal{N}(\boldsymbol{H}\boldsymbol{f},(1/\theta_e)\boldsymbol{I}), \\ p(\boldsymbol{f}|\theta_f;\mathcal{M}) &= \mathcal{N}(\boldsymbol{0},(1/\theta_f)(\boldsymbol{D}_f^t\boldsymbol{D}_f)^{-1}), \\ p(\theta_e;\mathcal{M}) &= \mathcal{G}(\alpha_{e0},\beta_{e0}), \\ p(\theta_f;\mathcal{M}) &= \mathcal{G}(\alpha_{f0},\beta_{f0}), \end{aligned} \tag{34}$$

où $\boldsymbol{D}_f$ est la matrice des différences finies d'ordre un ou deux et $\boldsymbol{\theta} = (\theta_e = 1/\sigma_\epsilon^2, \theta_f = 1/\sigma_f^2)$. On obtient alors facilement les expressions de $p(\boldsymbol{g},\boldsymbol{f}|\boldsymbol{\theta};\mathcal{M})$, $p(\boldsymbol{f}|\boldsymbol{\theta},\boldsymbol{g};\mathcal{M})$ et $p(\boldsymbol{\theta}|\boldsymbol{g},\boldsymbol{f};\mathcal{M})$

qui sont :

$$
\begin{aligned}
p(\boldsymbol{g},\boldsymbol{f}|\boldsymbol{H},\theta_e;\mathcal{M}) &= \mathcal{N}(\boldsymbol{H}\boldsymbol{f},(1/\theta_e)\boldsymbol{I})\times \\
&\quad \mathcal{N}\left(\boldsymbol{0},(1/\theta_f)(\boldsymbol{D}_f^t\boldsymbol{D}_f)^{-1}\right), \\
p(\boldsymbol{f}|\boldsymbol{g},\boldsymbol{H},\theta_f;\mathcal{M}) &= \mathcal{N}(\widehat{\boldsymbol{\mu}}_f,\widehat{\boldsymbol{\Sigma}}_f), \\
p(\theta_e|\boldsymbol{g};\mathcal{M}) &= \mathcal{G}(\widehat{\alpha}_e,\widehat{\beta}_e), \\
p(\theta_f|\boldsymbol{g};\mathcal{M}) &= \mathcal{G}(\widehat{\alpha}_f,\widehat{\beta}_f)
\end{aligned}
\tag{35}
$$

où les expressions de $\widehat{\boldsymbol{\mu}}_f$, $\widehat{\boldsymbol{\Sigma}}_f$, $(\widehat{\alpha}_e,\widehat{\beta}_e)$ et $(\widehat{\alpha}_f,\widehat{\beta}_f)$ sont :

$$
\begin{aligned}
\widehat{\boldsymbol{\Sigma}}_f &= [<\theta_e>\boldsymbol{H}^t\boldsymbol{H}+<\theta_f>\boldsymbol{D}_f^t\boldsymbol{D}_f]^{-1} \\
&= \tfrac{1}{<\theta_e>}[\boldsymbol{H}^t\boldsymbol{H}+\lambda\boldsymbol{D}_f^t\boldsymbol{D}_f]^{-1}, \text{ avec } \lambda=\tfrac{<\theta_f>}{<\theta_e>} \\
\widehat{\boldsymbol{\mu}}_f &= <\theta_e>\widehat{\boldsymbol{\Sigma}}_f\boldsymbol{H}^t\boldsymbol{g}, \\
\widehat{\alpha}_e &= \alpha_{e0}+M/2, \\
\widehat{\beta}_e &= \beta_{e0}+1/2<\boldsymbol{\epsilon}^t\boldsymbol{\epsilon}>, \\
\widehat{\alpha}_f &= \alpha_{f0}+N/2, \\
\widehat{\beta}_f &= \beta_{f0}+1/2\,\mathrm{Tr}\left\{\boldsymbol{D}_f^t\boldsymbol{D}_f<\boldsymbol{f}\boldsymbol{f}^t>\right\},
\end{aligned}
\tag{36}
$$

où

$$
\begin{aligned}
&<\boldsymbol{f}>=\widehat{\boldsymbol{\mu}}_f, \qquad <\boldsymbol{f}\boldsymbol{f}^t>=\widehat{\boldsymbol{\mu}}_f\widehat{\boldsymbol{\mu}}_f^t+\widehat{\boldsymbol{\Sigma}}_f, \\
&\qquad\qquad\qquad <\boldsymbol{\epsilon}^t\boldsymbol{\epsilon}>=[\boldsymbol{g}-\boldsymbol{H}\widehat{\boldsymbol{\mu}}_f]^t[\boldsymbol{g}-\boldsymbol{H}\widehat{\boldsymbol{\mu}}_f], \\
&<\theta_e>=\alpha_e/\beta_e, \quad <\theta_f>=\alpha_f/\beta_f
\end{aligned}
\tag{37}
$$

L'algorithme de mise à jour ici devient :

- Initialiser $\widehat{\alpha}_e=\alpha_{e0},\widehat{\beta}_e=\beta_{e0},\widehat{\alpha}_f=\alpha_{f0},\widehat{\beta}_f=\beta_{f0}$
- Mettre à jour jusqu'à la convergence :

  $<\theta_e>$ et $<\theta_f>$ puis $\widehat{\boldsymbol{\Sigma}}_f$ et puis $\widehat{\boldsymbol{\mu}}_f$

  et puis $\widehat{\alpha}_e$, $\widehat{\beta}_e$, $\widehat{\alpha}_f$, $\widehat{\beta}_f$.

La principale difficulté ici est l'inversion de la matrice $[\boldsymbol{H}^t\boldsymbol{H}+\lambda\boldsymbol{D}_f^t\boldsymbol{D}_f]$ qui est de dimensions trop grande. Une solution est de choisir pour $q(\boldsymbol{f}|\boldsymbol{g},\boldsymbol{\theta})$ aussi une loi séparable $q(\boldsymbol{f}|\boldsymbol{g},\boldsymbol{\theta})=\prod_j q(f_j|\boldsymbol{g},\boldsymbol{\theta})$. L'autre solution, comme nous la verrons dans la section suivante, est d'utiliser la structure spécifique de la matrice à inverser pour trouver un algorithme d'inversion convenable.

4 Application en restauration d'image

Dans le cas de la restauration d'image où $\boldsymbol{H}$ a une structure particulière, et où l'opération $\boldsymbol{H}\boldsymbol{f}$ représente une convolution de l'image f avec la réponse impulsionnelle h, la partie difficile et coûteuse de ces calculs est celle du calcul de $\widehat{\boldsymbol{f}}$ qui peut se faire à l'aide de la Transformée de Fourier rapide [52].

De même, l'approche peut être étendue pour le cas de la restauration aveugle ou myope où on cherche à la fois d'estimer la réponse impulsionnelle $\boldsymbol{h}$, l'image $\boldsymbol{f}$ et les hyperparamètres $\boldsymbol{\theta}$. Pour établir l'expressions des différentes lois dans ce cas, nous notons que le problème direct, suivant que l'on s'intéresse à $\boldsymbol{f}$ (déconvolution) ou à $\boldsymbol{h}$ (identification de la réponse impulsionnelle), peux s'écrire

$$\begin{aligned} g(\boldsymbol{r}) &= h(\boldsymbol{r}) * f(\boldsymbol{r}) + \epsilon(\boldsymbol{r}) = f(\boldsymbol{r}) * h(\boldsymbol{r}) + \epsilon(\boldsymbol{r}) \\ \boldsymbol{g} &= \boldsymbol{H}\ \boldsymbol{f} + \boldsymbol{\epsilon} = \boldsymbol{F}\ \boldsymbol{h} + \boldsymbol{\epsilon} \end{aligned} \tag{38}$$

où la matrice $\boldsymbol{H}$ est entièrement définie par le vecteur $\boldsymbol{h}$ et la matrice $\boldsymbol{F}$ est entièrement définie par le vecteur $\boldsymbol{f}$.

Pour permettre d'obtenir une solution bayésienne pour l'étape de l'identification, nous devons aussi modéliser $\boldsymbol{h}$. Une solution est de supposer $\boldsymbol{h} = \boldsymbol{\Phi}\boldsymbol{w}$ où la matrice $\boldsymbol{\Phi}$ est une matrice telle que $\boldsymbol{\Phi}\boldsymbol{w}$ représente la convolution $\phi(\boldsymbol{r}) * w(\boldsymbol{r})$. Ainsi les colonnes de $\boldsymbol{\Phi}$ représentent une base et les éléments du vecteur $\boldsymbol{w}$ représentent les coefficients de la décomposition de h sur cette base. On a ainsi

$$\begin{aligned} g(\boldsymbol{r}) &= (\phi * w) * f(\boldsymbol{r}) + \epsilon(\boldsymbol{r}) = f * (\phi * w)(\boldsymbol{r}) + \epsilon(\boldsymbol{r}) \\ \boldsymbol{g} &= \boldsymbol{\Phi}\ \boldsymbol{W}\ \boldsymbol{f} + \boldsymbol{\epsilon} = \boldsymbol{F}\ \boldsymbol{\Phi}\ \boldsymbol{w} + \boldsymbol{\epsilon} \end{aligned} \tag{39}$$

où la matrice $\boldsymbol{W}$ est entièrement définie par le vecteur $\boldsymbol{w}$.

Le problème de la déconvolution aveugle se ramène à l'estimation de $\boldsymbol{f}$ et $\boldsymbol{w}$ avec des lois

$$p(\boldsymbol{g}|\boldsymbol{w}, \boldsymbol{f}, \boldsymbol{\Sigma}_\epsilon) = \mathcal{N}(\boldsymbol{\Phi}\boldsymbol{W}\boldsymbol{f}, \boldsymbol{\Sigma}_\epsilon) = \mathcal{N}(\boldsymbol{F}\boldsymbol{\Phi}\boldsymbol{w}, \boldsymbol{\Sigma}_\epsilon) \tag{40}$$

avec

$$\begin{aligned} \boldsymbol{\Sigma}_\epsilon = \text{diag}\left[\frac{1}{\theta_{e_i}}, i = 1, \cdots, M\right] \text{ et } p(\theta_{e_i}) = \mathcal{G}(\alpha_{e0}, \beta_{e0}), \\ p(\boldsymbol{f}|\theta_f) = \mathcal{N}\left(\boldsymbol{0}, (\theta_f \boldsymbol{D}_f^t \boldsymbol{D}_f)^{-1}\right) \end{aligned} \tag{41}$$

avec

$$p(\theta_f) = \mathcal{G}(\alpha_{f0}, \beta_{f0}),$$

et

$$p(\boldsymbol{w}|\boldsymbol{\alpha}) = \prod_j p(w_j|\alpha_{w_j}) = \prod_j \mathcal{N}(0, \frac{1}{\alpha_{w_j}}) \tag{42}$$

avec

$$p(\boldsymbol{\alpha}) = \prod_j p(\alpha_{w_j}) = \prod_j \mathcal{G}(a_0, b_0).$$

Avec ces lois *a priori* , il est alors facile de trouver l'expression de la loi conjointe $p(\boldsymbol{f}, \boldsymbol{w}, \boldsymbol{\Sigma}_\epsilon, \theta_f, \boldsymbol{\alpha}; \boldsymbol{g})$ et la loi *a posteriori* $p(\boldsymbol{f}, \boldsymbol{w}, \boldsymbol{\Sigma}_\epsilon, \theta_f, \boldsymbol{\alpha}|\boldsymbol{g})$. Cependant l'expression de cette loi

$$\begin{aligned} p(\boldsymbol{f}, \boldsymbol{w}, \boldsymbol{\Sigma}_\epsilon, \theta_f, \boldsymbol{\alpha}|\boldsymbol{g}) \propto \quad & p(\boldsymbol{g}|\boldsymbol{w}, \boldsymbol{f}, \boldsymbol{\Sigma}_\epsilon)\, p(\boldsymbol{f}|\theta_f)\, p(\boldsymbol{w}|\boldsymbol{\alpha}) \\ & p(\theta_e)\, p(\theta_f)\, p(\boldsymbol{\alpha}) \end{aligned} \tag{43}$$

n'est pas séparable en ses composantes. L'approche variationnelle consiste donc à l'approcher par une loi séparable

$$p(\boldsymbol{f}, \boldsymbol{w}, \boldsymbol{\theta}_e, \theta_f, \boldsymbol{\alpha}|\boldsymbol{g}) \simeq q(\boldsymbol{f}) q(\boldsymbol{w}) \prod_i q(\theta_{e_i}) q(\theta_f) \prod_j q(\alpha_{w_j}) \tag{44}$$

et avec les choix des lois *a priori* conjuguées en appliquant la procédure décrite plus haut, on obtient

$$\begin{aligned} q(\boldsymbol{f}) &= \mathcal{N}(\boldsymbol{\mu}_f, \boldsymbol{\Sigma}_f) \text{ avec} \\ \boldsymbol{\Sigma}_f &= [\boldsymbol{\Phi}^t < \boldsymbol{W}^t \boldsymbol{B} \boldsymbol{W} > \boldsymbol{\Phi} + < \theta_f > \boldsymbol{D}_f^t \boldsymbol{D}_f]^{-1}, \\ \boldsymbol{\mu}_f &= \boldsymbol{\Sigma}_f \boldsymbol{\Phi}^t < \boldsymbol{W} >^t \boldsymbol{B}\boldsymbol{g}, \end{aligned} \tag{45}$$

$$\begin{aligned} q(\boldsymbol{w}) &= \mathcal{N}(\boldsymbol{\mu}_w, \boldsymbol{\Sigma}_w) \text{ avec} \\ \boldsymbol{\Sigma}_w &= [\boldsymbol{\Phi}^t < \boldsymbol{F}^t \boldsymbol{B} \boldsymbol{F} > \boldsymbol{\Phi} + \boldsymbol{A}]^{-1}, \\ \boldsymbol{\mu}_w &= \boldsymbol{\Sigma}_w \boldsymbol{\Phi}^t < \boldsymbol{F} >^t \boldsymbol{B}\boldsymbol{g} \end{aligned} \tag{46}$$

$$\begin{aligned} q(\theta_{e_i}) &= \mathcal{G}(\alpha_{ei}, \beta_{ei}) \text{ avec} \\ \alpha_{ei} &= \alpha_{e0} + M/2, \\ \beta_{ei} &= \beta_{e0} + 1/2 < \boldsymbol{\epsilon}\boldsymbol{\epsilon}^t >_{ii}, \end{aligned} \tag{47}$$

$$\begin{aligned} q(\theta_f) &= \mathcal{G}(\alpha_f, \beta_f) \text{ avec} \\ \alpha_f &= \alpha_{f0} + N/2, \\ \beta_f &= \beta_{f0} + 1/2 \operatorname{Tr}\left\{\boldsymbol{D}_f^t \boldsymbol{D}_f < \boldsymbol{f}\boldsymbol{f}^t >\right\}, \end{aligned} \tag{48}$$

$$
\begin{aligned}
q(\alpha_{wj}) &= \mathcal{G}(a_j, b_j) \text{ avec} \\
a_j &= \alpha_{w0} + 1/2, \\
b_j &= \beta_{w0} + 1/2 < w_j^2 > .
\end{aligned} \tag{49}
$$

où

$$
\begin{aligned}
\boldsymbol{A} &= \text{diag}\left[< \alpha_{wj} >, j = 1, \cdots, N\right] \text{ et} \\
\boldsymbol{B} &= \text{diag}\left[< \beta_{ei} >, i = 1, \cdots, M\right].
\end{aligned}
$$

On a ainsi l'expression des différentes composante de la loi séparable approchante. On peut en déduire facilement les moyennes de ces lois, car ces lois sont, soit des gaussiennes, soit des lois gamma.

$$
\begin{array}{ll}
< \boldsymbol{w} >= \boldsymbol{\mu}_w, & < w_j^2 >= [\boldsymbol{\mu}_w]_j^2 + [\boldsymbol{\Sigma}_w]_{jj} \\
< \boldsymbol{f} >= \boldsymbol{\mu}_f, & < \boldsymbol{f}\boldsymbol{f}^t >= \boldsymbol{\mu}_f \boldsymbol{\mu}_f^t + \boldsymbol{\Sigma}_f \\
< \theta_{ei} >= \alpha_{ei}/\beta_{ei} & < \theta_f >= \alpha_f/\beta_f,
\end{array} \tag{50}
$$

et

$$
\begin{aligned}
< \boldsymbol{\epsilon}\boldsymbol{\epsilon}^t > &= \boldsymbol{g}\boldsymbol{g}^t - 2\boldsymbol{g}[< \boldsymbol{F} > \boldsymbol{\Phi} < \boldsymbol{w} >]^t \\
&+ \boldsymbol{\Phi}[\boldsymbol{F} < \boldsymbol{w} >< \boldsymbol{w} >^t \boldsymbol{F}^t]\boldsymbol{\Phi}^t
\end{aligned} \tag{51}
$$

Pour le calcul des termes $< \boldsymbol{W}^t\boldsymbol{W} >$ et $< \boldsymbol{F}^t\boldsymbol{F} >$ qui interviennent dans les expressions de $\boldsymbol{\Sigma}_f$, $\boldsymbol{\Sigma}_w$ et $[\boldsymbol{F}\boldsymbol{w}\boldsymbol{w}^t\boldsymbol{F}^t]$ on peut utiliser le fait que $\boldsymbol{F}$ et $\boldsymbol{W}$ sont des matrices bloc-Toeplitz avec des blocs Toeplitz (TBT), on peut les approcher par des matrices bloc-circulantes avec des blocs circulantes (CBC) et les inverser en utilisant la TFD. Notons aussi que $\boldsymbol{\mu}_f$ et $\boldsymbol{\mu}_w$ peuvent être obtenu par optimisation de

$$
J(\boldsymbol{\mu}_f) = [\boldsymbol{g} - \boldsymbol{\Phi}\boldsymbol{W}\boldsymbol{\mu}_f]^t\boldsymbol{B}[\boldsymbol{g} - \boldsymbol{\Phi}\boldsymbol{W}\boldsymbol{\mu}_f] + < \theta_f > \|\boldsymbol{D}_f\boldsymbol{\mu}_f\|^2 \tag{52}
$$

et de

$$
J(\boldsymbol{\mu}_w) = [\boldsymbol{g} - \boldsymbol{\Phi}\boldsymbol{F}\boldsymbol{\mu}_w]^t\boldsymbol{B}[\boldsymbol{g} - \boldsymbol{\Phi}\boldsymbol{F}\boldsymbol{\mu}_w] + \|\boldsymbol{A}\boldsymbol{\mu}_w\|^2. \tag{53}
$$

5 Restauration avec modélisation Gauss-Markov-Potts

Le cas d'une modélisation gaussienne reste assez restrictif pour la modélisation des images. Des modélisation par des champs de Markov composites (intensités-contours ou intensités-régions) sont mieux adaptées. Dans ce travail, nous examinons ce dernier. L'idée

de base est de classer les pixels de l'images $\boldsymbol{f} = \{f(\boldsymbol{r}), \boldsymbol{r} \in \mathcal{R}\}$ en K classes par l'intermédiaire d'une variable discrète $z(\boldsymbol{r}) \in \{1, \cdots, K\}$. L'image $\boldsymbol{z} = \{z(\boldsymbol{r}), \boldsymbol{r} \in \mathcal{R}\}$ représente ainsi la segmentation de l'image $\boldsymbol{f}$. Les pixels $\boldsymbol{f}_k = \{f(\boldsymbol{r}), \boldsymbol{r} \in \mathcal{R}_k\}$ avec $\mathcal{R}_k = \{\boldsymbol{r} \ : \ z(\boldsymbol{r}) = k\}$ ont des propriétés communes, par exemple la même moyenne μ_k et la même variance v_k (homogénéité au sens probabiliste). Ces pixels se trouvent dans un nombre fini de régions compactes et disjointes $\mathcal{R}_{kl}$ telles que : $\cup_l \mathcal{R}_{kl} = \mathcal{R}_k$ et $\cup_k \mathcal{R}_k = \mathcal{R}$. On suppose aussi que $\boldsymbol{f}_k$ et $\boldsymbol{f}_l$ $\forall k \neq l$ sont indépendants.

A chaque région est associée un contour. Si on représente les contours de l'images par une variable binaire $c(\boldsymbol{r})$, on a $c(\boldsymbol{r}) = 0$ à l'intérieure d'une région et $c(\boldsymbol{r}) = 1$ aux frontières de ces régions. On note aussi que $c(\boldsymbol{r})$ s'obtient à partir de $z(\boldsymbol{r})$ d'une manière déterministe (voir Fig 1).

Avec cette introduction, nous pouvons définir

$$p(f(\boldsymbol{r})|z(\boldsymbol{r}) = k, m_k, v_k) = \mathcal{N}(m_k, v_k) \tag{54}$$

ce qui suggère un modèle de mélange de gaussienne pour les pixels de l'image

$$p(f(\boldsymbol{r})) = \sum_k a_k \mathcal{N}(m_k, v_k) \text{ avec } a_k = P(z(\boldsymbol{r}) = k) \tag{55}$$

Une première modélisation simple est de supposer que les étiquettes $z(\boldsymbol{r})$ sont *a priori* indépendants :

$$p(\boldsymbol{z}) = \prod_{\boldsymbol{r}} p(z(\boldsymbol{r})). \tag{56}$$

Nous appelons ce modèle, Mélange séparable de gaussiennes (MSG).

Maintenant, pour prendre en compte la structure spatiale de ces pixels, nous devons introduire, d'une manière ou autre, une dépendance spatiale entre ces pixels. La modélisation markovienne est justement l'outil approprié.

Cette dépendance spatiale peut être fait de trois manières. Soit utiliser un modèle markovien pour $z(\boldsymbol{r})$ et un modèle indépendant pour $f(\boldsymbol{r})|z(\boldsymbol{r})$, soit un modèle markovien pour $f(\boldsymbol{r})|z(\boldsymbol{r})$ et un modèle indépendant pour $z(\boldsymbol{r})$, soit un modèle markovien pour $f(\boldsymbol{r})|z(\boldsymbol{r})$ et un modèle markovien aussi pour $z(\boldsymbol{r})$. Nous avons examiné ces cas avec des modèles de Gauss-Markov pour $f(\boldsymbol{r})|z(\boldsymbol{r})$ et le modèle de Potts pour $z(\boldsymbol{r})$. Ce dernier peut s'écrire sous deux formes :

$$p(z(\boldsymbol{r})|z(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})) \propto \exp\left[\gamma \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}'))\right] \tag{57}$$

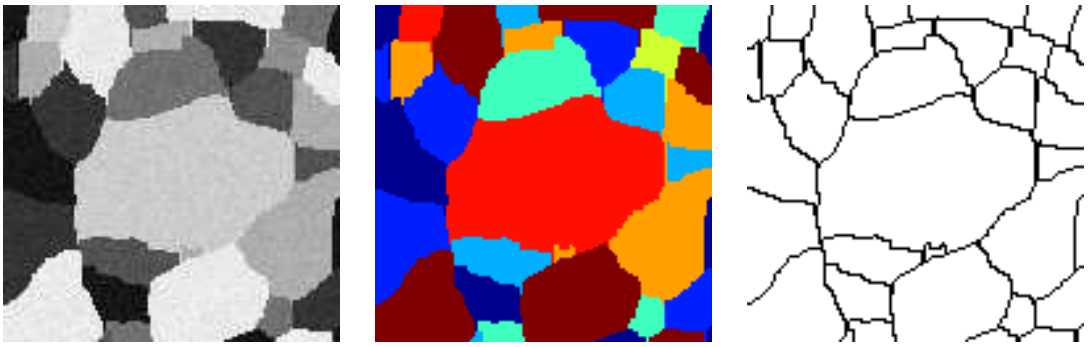

$f(\boldsymbol{r})$ $z(\boldsymbol{r})$ $c(\boldsymbol{r})$

FIG. 1 – Modèle de mélange et champs de Markov caché : image des intensités ou niveau de gris $f(\boldsymbol{r})$, image $z(\boldsymbol{r})$ de segmentation ou classification, image binaire $c(\boldsymbol{r})$ des contours.

et

$$p(\boldsymbol{z}) \propto \exp\left[\gamma \sum_{\boldsymbol{r}\in\mathcal{R}} \sum_{\boldsymbol{r}'\in\mathcal{V}(\boldsymbol{r})} \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}'))\right] \tag{58}$$

Ces différents cas peuvent alors se résumer par :

Modèle de mélange séparables de gaussiennes (MSG) :

C'est le modèle le plus simple où aucune structure spatiale n'est pris en compte *a priori* . Les relations qui donnent la loi *a priori* conjointe de $p(\boldsymbol{f}, \boldsymbol{z}) = p(\boldsymbol{f}|\boldsymbol{z})\, p(\boldsymbol{z})$ sont :

$$\left\{\begin{array}{lcl} p(f(\boldsymbol{r})|z(\boldsymbol{r}) = k) & = & \mathcal{N}(m_k, v_k), \forall \boldsymbol{r} \in \mathcal{R} \\ p(\boldsymbol{f}|\boldsymbol{z}) & = & \prod_{\boldsymbol{r}\in\mathcal{R}} \mathcal{N}(m_z(\boldsymbol{r}), v_z(\boldsymbol{r})) \end{array}\right. \tag{59}$$

avec $m_z(\boldsymbol{r}) = m_k, \forall \boldsymbol{r} \in \mathcal{R}_k$ et $v_z(\boldsymbol{r}) = v_k, \forall \boldsymbol{r} \in \mathcal{R}_k$, et

$$\left\{\begin{array}{lcl} p(z(\boldsymbol{r}) = k) & = & \alpha_k,\ \forall \boldsymbol{r} \in \mathcal{R} \\ p(\boldsymbol{z}) & = & \prod_{\boldsymbol{r}} p(z(\boldsymbol{r}) = k) = \prod_k \alpha_k^{n_k} \end{array}\right. \tag{60}$$

avec $n_k = \sum_{\boldsymbol{r}\in\mathcal{R}} \delta(z(\boldsymbol{r}) - k)$ le nombre de pixels dans la classe k et $\sum_k n_k = n$ le nombre total des pixels de l'image. Les paramètres de ce modèle sont

$$\boldsymbol{\theta}_f = \{(\alpha_k, m_k, v_k), k = 1, \cdots, K\}.$$

Rappelons aussi que $\sum_k \alpha_k = 1$. Lors d'une estimation bayésienne non supervisée, il faut aussi attribuer des lois *a priori* à ces paramètres. les lois conjuguées correspondantes sont des gaussiennes pour m_k, des Inverse Gammas pour v_k et la loi Dirichlet pour $\boldsymbol{\alpha} = [\alpha_k, k = 1, \cdots, K]$:

$$\left\{\begin{array}{lcl} p(m_k|m_0,v_0) & = & \mathcal{N}(m_0,v_0),\ \forall k \\ p(v_k|\alpha_0,\beta_0) & = & \mathcal{IG}(a_0,b_0),\ \forall k \\ p(\boldsymbol{\alpha}|\alpha_0) & = & \mathcal{D}(\alpha_0\mathbf{1}_K) \end{array}\right. \tag{61}$$

où m_0, v_0, a_0, b_0 et α_0 sont fixés pour un problème donnée. On les choisis de telle sorte que ces lois soient les moins informatives (par exemple, $m_0 = 0$, $v_0 = 10$, $a_0 = 1$, $b_0 = 100$ et $\alpha_0 = 1/K$).

Modèle de mélange séparable de Gauss-Markov (MSGM) :

Ici, la structure spatiale est pris en compte au travers d'un modèle markovien sur $\boldsymbol{f}$:

$$p(f(\boldsymbol{r})|z(\boldsymbol{r}), f(\boldsymbol{r}'), z(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})) = \mathcal{N}(m_z(\boldsymbol{r}), v_z(\boldsymbol{r})) \tag{62}$$

avec

$$\begin{array}{lcl} m_z(\boldsymbol{r}) & = & \frac{1}{|\mathcal{V}(\boldsymbol{r})|}\sum_{\boldsymbol{r}'\in\mathcal{V}(\boldsymbol{r})} m^*_{z(\boldsymbol{r}')} \\ m^*_{z(\boldsymbol{r}')} & = & \left\{\begin{array}{lll} \mu_{z(\boldsymbol{r}')} & \text{si} & z(\boldsymbol{r}') \neq z(\boldsymbol{r}) \\ f(\boldsymbol{r}') & \text{si} & z(\boldsymbol{r}') = z(\boldsymbol{r}) \end{array}\right. \end{array} \tag{63}$$

Par contre le champs $\boldsymbol{z}$ est supposé séparable comme dans le premier cas (60).

On remarque que $\boldsymbol{f}|\boldsymbol{z}$ est un champ de Gauss-Markov non homogène car la moyenne $m_z(\boldsymbol{r})$ et la variance $v_z(\boldsymbol{r})$ varient en fonction de $\boldsymbol{r}$. Tous les pixels $\boldsymbol{f}_k = \{f(\boldsymbol{r}), \boldsymbol{r} \in \mathcal{R}_k\}$ se trouvant dans une région k forment alors un vecteur gaussien de moyen $m_k\mathbf{1}_k$ et de matrice de covariance $\boldsymbol{\Sigma}_k$:

$$p(\boldsymbol{f}_k) = \mathcal{N}(m_k\mathbf{1}_k, v_k\boldsymbol{\Sigma}_k) \tag{64}$$

où $v_k\boldsymbol{\Sigma}_k$ est une matrice de covariance de dimension $n_k \times n_k$ et $\mathbf{1}_k = 1$ est un vecteur de taille n_k remplis de 1. Par ailleurs, on a aussi :

$$p(\boldsymbol{f}|\boldsymbol{z}) \propto \prod_k \mathcal{N}(m_k\mathbf{1}_k, v_k\boldsymbol{\Sigma}_k) \tag{65}$$

ce qui signifie que les pixels appartenant aux différentes régions sont indépendantes.

Modèle de Gauss-Potts (MGP) :

Dans ce modèle, la structure spatiale est pris en compte au travers du modèle markovien de Potts (57) ou (58). La loi de $p(\boldsymbol{f}|\boldsymbol{z})$ est la même que dans le premier cas. En résumé, ici on a :

$$\left\{\begin{array}{lcl} p(\boldsymbol{f}|\boldsymbol{z}) & = & \prod_{\boldsymbol{r}\in\mathcal{R}} \mathcal{N}(m(\boldsymbol{r}), v(\boldsymbol{r})) \\ p(\boldsymbol{z}) & \propto & \exp\left[\gamma \sum_{\boldsymbol{r}\in\mathcal{R}} \sum_{\boldsymbol{r}'\in\mathcal{V}(\boldsymbol{r})} \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}'))\right] \end{array}\right. \tag{66}$$

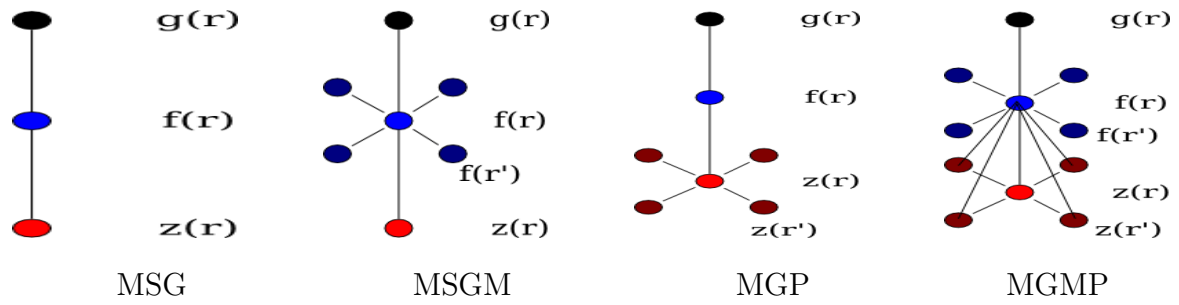

FIG. 2 – Quatre modèles de mélange avec champs cachés. Dans le modèle MSG toutes les variables sont séparables en $\boldsymbol{r}$. Dans MSGM, $f(\boldsymbol{r})$ dépends de $z(\boldsymbol{r})$ et de ses voisins $f(\boldsymbol{r}')$. Dans MGP, $z(\boldsymbol{r})$ dépends de ses voisin $z(\boldsymbol{r}')$. Dans MGMP, $z(\boldsymbol{r})$ dépends de ses voisin $z(\boldsymbol{r}')$ et $f(\boldsymbol{r})$ dépends de $z(\boldsymbol{r})$, $z(\boldsymbol{r}')$ et de ses voisins $f(\boldsymbol{r}')$.

avec $m(\boldsymbol{r}) = m_k, \forall \boldsymbol{r} \in \mathcal{R}_k$ et $v(\boldsymbol{r}) = v_k, \forall \boldsymbol{r} \in \mathcal{R}_k$.

Ici, donc, les pixels de l'images sont indépendantes conditionnellement à la connaissance des variables cachées, et donc, contrairement au cas précédent (64), ici on a $p(\boldsymbol{f}_k) = \mathcal{N}(m_k \mathbf{1}_k, v_k \boldsymbol{I}_k)$ où $v_k \boldsymbol{I}_k$ est une matrice de covariance identité de dimension $n_k \times n_k$, ce qui permet d'écrire :

$$p(\boldsymbol{f}_k) = \mathcal{N}(m_k \mathbf{1}_k, v_k \boldsymbol{I}_k) \propto \exp\left[\frac{-1}{2} \sum_{\boldsymbol{r} \in \mathcal{R}_k} \frac{f(\boldsymbol{r}) - m_k)^2}{v_k}\right] \tag{67}$$

et

$$\begin{aligned} p(\boldsymbol{f}|\boldsymbol{z}) &\propto \prod_k \mathcal{N}(m_k \mathbf{1}_k, \boldsymbol{I}_k) \\ &\propto \exp\left[\frac{-1}{2} \sum_k \sum_{\boldsymbol{r} \in \mathcal{R}_k} \frac{(f(\boldsymbol{r}) - m_k)^2}{v_k}\right] \end{aligned} \tag{68}$$

ce qui signifie que, comme le cas précédent, les pixels appartenant aux différentes régions sont indépendantes.

Les paramètres de ce modèle sont $\boldsymbol{\theta}_f = \{(\alpha_k, m_k, v_k), k = 1, \cdots, K\}$ et γ. Malheureusement, il n'y a pas de loi conjuguée pour ce paramètre et donc son estimation devient plus difficile. Dans ce travail, nous fixons ce paramètre *a priori* .

Modèle de Gauss-Markov-Potts (MGMP) :

Il s'agit là de la composition des deux derniers modèles. Ici, nous résumons ses relations

d'une manière légèrement différente en utilisant :

$$c_{\boldsymbol{r}}(\boldsymbol{r}') = 1 - \delta(z(\boldsymbol{r}') - z(\boldsymbol{r})) = \begin{cases} 1 & \text{si} \quad z(\boldsymbol{r}') \neq z(\boldsymbol{r}) \\ 0 & \text{si} \quad z(\boldsymbol{r}') = z(\boldsymbol{r}) \end{cases} \tag{69}$$

ce qui donne :

$$p(f(\boldsymbol{r})|z(\boldsymbol{r}), f(\boldsymbol{r}'), z(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})) = \mathcal{N}(m_z(\boldsymbol{r}), v_z(\boldsymbol{r})) \tag{70}$$

avec

$$m_z(\boldsymbol{r}) = \frac{1}{|\mathcal{V}(\boldsymbol{r})|} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \left[(1 - c_{\boldsymbol{r}}(\boldsymbol{r}'))\mu_{z(\boldsymbol{r}')} + c_{\boldsymbol{r}}(\boldsymbol{r}') f(\boldsymbol{r}') \right] \tag{71}$$

et

$$p(\boldsymbol{z}) \propto \exp\left[\gamma \sum_{\boldsymbol{r} \in \mathcal{R}} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} (1 - c_{\boldsymbol{r}}(\boldsymbol{r}')) \right] \tag{72}$$

En tous cas, quelque soit le modèle choisi parmi ces différents modèles, l'objectif est d'estimer $\boldsymbol{f}$, $\boldsymbol{z}$ et $\boldsymbol{\theta}$ en utilisant la loi *a posteriori* jointe :

$$p(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta}|\boldsymbol{g}) = \frac{p(\boldsymbol{g}|\boldsymbol{f}, \boldsymbol{\theta})\ p(\boldsymbol{f}|\boldsymbol{z}, \boldsymbol{\theta})\ p(\boldsymbol{z})}{p(\boldsymbol{g}|\boldsymbol{\theta})} \tag{73}$$

Bien que nous connaissons les expressions de tous les composants de numérateur de la fraction à la droite de cette relation, le calcul du dénominateur n'est que rarement possible d'une manière analytique. On cherche alors à approcher $p(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta}|\boldsymbol{g})$ par un produit des lois plus simples à manipuler. Un premier choix est de l'approcher par une loi séparable $q(\boldsymbol{f}, \boldsymbol{z}, \boldsymbol{\theta}|\boldsymbol{g}) = q_1(\boldsymbol{f})\ q_2(\boldsymbol{z})\ q_3(\boldsymbol{\theta})$. Un deuxième choix est $q_1(\boldsymbol{f}|\boldsymbol{z})\ q_2(\boldsymbol{z})\ q_3(\boldsymbol{\theta})$ qui permet de garder des liens forts qui existent entre $\boldsymbol{f}$ et $\boldsymbol{z}$ et de ne relaxer que des liens faibles entre $\boldsymbol{\theta}$ et ces deux derniers.

Le choix des familles appropriées pour $q_1(\boldsymbol{f}|\boldsymbol{z})$ et $q_2(\boldsymbol{z})$ et $q_3(\boldsymbol{\theta})$ pour chacun de ces modèles, qui est en lien avec les formes des lois *a priori* dans chacun de ces cas, et les expressions de la mise à jour de ces différentes lois au cours des itérations nécessite beaucoup d'espace. Ici, nous allons juste fournir le principe et un résumé de ces relations.

Le choix de $q_3(\boldsymbol{\theta})$, ou plus exactement, des familles des lois pour chacune des composentes de $\boldsymbol{\theta}$, qui sont la même pour tous les cas, sont des lois conjuguées de (61). Par la suite, nous détaillons les choix de $q(\boldsymbol{f}|\boldsymbol{z})$ et $q(\boldsymbol{z})$ dans les différent cas.

Cas 1 (MSG) :

Dans le cas du premier modèle on a

$$\begin{cases} p(\boldsymbol{f}|\boldsymbol{z}) &= \prod_{\boldsymbol{r}} p(f(\boldsymbol{r})|z(\boldsymbol{r})) \\ p(\boldsymbol{z}) &= \prod_{\boldsymbol{r}} p(z(\boldsymbol{r})) \end{cases} \tag{74}$$

où $p(f(\boldsymbol{r})|z(\boldsymbol{r}) = k) = \mathcal{N}(m_k, v_k)$ et $p(z(\boldsymbol{r}) = k) = \alpha_k$, ce qui naturellement nous conduit à choisir

$$\begin{cases} q(\boldsymbol{f}|\boldsymbol{z}) &= \prod_{\boldsymbol{r}} q(f(\boldsymbol{r})|z(\boldsymbol{r})) \\ q(\boldsymbol{z}) &= \prod_{\boldsymbol{r}} q(z(\boldsymbol{r})) \end{cases} \tag{75}$$

avec $q(f(\boldsymbol{r})|z(\boldsymbol{r}) = k) = \mathcal{N}(\tilde{m}_k, \tilde{v}_k)$ et $q(z(\boldsymbol{r}) = k) = \tilde{\alpha}_k$.

Au cours des itérations, $\tilde{m}_k$ $\tilde{v}_k$ et $\tilde{\alpha}_k$ seront mise à jour.

Cas 2 (MSGM) :

Dans le deuxième cas, le modèle de mélange de Gauss-Markov, notant que

$$p(\boldsymbol{f}|\boldsymbol{z}) = \prod_{\boldsymbol{r}} \mathcal{N}(f(\boldsymbol{r})|m_z(\boldsymbol{r}), v_z(\boldsymbol{r})) \tag{76}$$

où

$$m_z(\boldsymbol{r}) = \frac{1}{|\mathcal{V}(\boldsymbol{r})|} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} m^*_{z(\boldsymbol{r}')} \tag{77}$$

avec

$$m^*_{z(\boldsymbol{r}')} = \delta(z(\boldsymbol{r}') - z(\boldsymbol{r}))f(\boldsymbol{r}') + (1 - \delta(z(\boldsymbol{r}') - z(\boldsymbol{r}))\mu_{z(\boldsymbol{r}')} \tag{78}$$

on trouve naturellement l'approximation suivante :

$$m^*_{z(\boldsymbol{r}')} = \delta(z(\boldsymbol{r}') - z(\boldsymbol{r}))\tilde{f}(\boldsymbol{r}') + (1 - \delta(z(\boldsymbol{r}') - z(\boldsymbol{r}))\tilde{m}_{z(\boldsymbol{r})} \tag{79}$$

où $\tilde{f}(\boldsymbol{r}')$ est l'espérance de $f(\boldsymbol{r}')$ calculée à l'étape précédente. Il s'agit de l'approximation dite *en champs moyens* pour le champ de Markov $\boldsymbol{f}$:

$$\begin{cases} q(\boldsymbol{f}|\boldsymbol{z}) = \prod_{\boldsymbol{r}} q(f(\boldsymbol{r})|z(\boldsymbol{r})) = \prod_{\boldsymbol{r}} \mathcal{N}(f(\boldsymbol{r})|m_z(\boldsymbol{r}), v_z(\boldsymbol{r})) \\ \text{avec} \\ m_z(\boldsymbol{r}) = \frac{1}{|\mathcal{V}(\boldsymbol{r})|} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \\ \qquad \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}'))f(\boldsymbol{r}) + (1 - \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}')))\mu_{z(\boldsymbol{r})} \end{cases} \tag{80}$$

Cas 3 (MGP) :

Dans le troisième cas, le modèle de Gauss-Potts on a

$$\begin{cases} p(\boldsymbol{f}|\boldsymbol{z}) &= \prod_{\boldsymbol{r}} p(f(\boldsymbol{r})|z(\boldsymbol{r})) \\ p(\boldsymbol{z}) &= \prod_{\boldsymbol{r}} p(z(\boldsymbol{r})|z(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})) \end{cases} \tag{81}$$

ce qui naturellement nous conduit à choisir

$$\begin{cases} q(\boldsymbol{f}|\boldsymbol{z}) &= \prod_{\boldsymbol{r}} q(f(\boldsymbol{r})|z(\boldsymbol{r})) \\ q(\boldsymbol{z}) &= \prod_{\boldsymbol{r}} q(z(\boldsymbol{r})|\bar{z}(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})) \end{cases} \tag{82}$$

où nous avons choisi une approximation en champs moyens pour le champs de Potts. Cette approximation supplémentaire qui consiste à remplacer les valeurs de $z(\boldsymbol{r}')$ par leurs moyenne $\bar{z}(\boldsymbol{r}')$ est une approximation courante pour un modèle de Potts.

Cas 4 (MGMP) :

Dans le quatrième cas,le Modèle de Gauss-Markov-Potts on a

$$\begin{cases} q(\boldsymbol{f}|\boldsymbol{z}) = \prod_{\boldsymbol{r}} q(f(\boldsymbol{r})|z(\boldsymbol{r})) = \prod_{\boldsymbol{r}} \mathcal{N}(f(\boldsymbol{r})|m_z(\boldsymbol{r}), v_z(\boldsymbol{r})) \\ \text{avec} \\ m_z(\boldsymbol{r}) = \frac{1}{|\mathcal{V}(\boldsymbol{r})|} \sum_{\boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})} \\ \qquad \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}')f(\boldsymbol{r}) + (1 - \delta(z(\boldsymbol{r}) - z(\boldsymbol{r}'))\mu_{z(\boldsymbol{r})} \\ q(\boldsymbol{z}) = \prod_{\boldsymbol{r}} q(z(\boldsymbol{r})|\bar{z}(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r})) \end{cases} \tag{83}$$

Dans tous les cas, puisque les lois *a priori* pour les différent composants de $\boldsymbol{\theta} = \{\{\theta_{e_i}\}, \{m_k\}, \{v_k\}, \{\beta_k\}\}$ sont des lois conjuguées et séparables, on choisi

$$q(\boldsymbol{\theta}) = \prod_i q(\theta_i) \tag{84}$$

Il reste un paramètre que nous garderons fixe. C'est le paramètre du modèle de Potts. En effet, n'ayant pas une expression analytique pour la fonction de répartition du modèle de Potts, il n'existe pas une loi conjuguée pour ce paramètre. Dans un premier temps donc, nous gardons ce paramètre comme un paramètre de réglage non supervisé.

Les deux tableaux qui suivent résument les lois *a priori* et les choix des lois séparables pour les quatre cas proposés.

Ici, nous ne développons pas plus les expressions de la mise à jour de ces différentes loi au cours des itérations, mais ce qu'il faut savoir est que toutes ces lois étant de formes paramétriques connues (gaussienne, gamma ou inverse gamma, Wishart ou inverse Wishart et Dirichlet), nous avons des expressions analytiques pour les espérances de ces lois. Les détails de ces relations accompagnés des résultats de simulation seront communiqués dans un autre papier dans un future proche.

Modèle	MSG	MSGM	MGP	MGMP
$p(\boldsymbol{f}\|\boldsymbol{z})$	$\prod_{\boldsymbol{r}} \mathcal{N}(m_z(\boldsymbol{r}), v_z(\boldsymbol{r}))$	Gauss-Markov	$\prod_{\boldsymbol{r}} \mathcal{N}(m_z(\boldsymbol{r}), v_z(\boldsymbol{r}))$	Gauss-Markov
$p(\boldsymbol{z})$	$\prod_{\boldsymbol{r}} \alpha_z(\boldsymbol{r}) = \prod_k \alpha_k^{n_k}$	$\prod_{\boldsymbol{r}} \alpha_z(\boldsymbol{r}) = \prod_k \alpha_k^{n_k}$	Potts	Potts
$p(m_k)$	$\mathcal{N}(m_0, v_0)$	$\mathcal{N}(m_0, v_0)$	$\mathcal{N}(m_0, v_0)$	$\mathcal{N}(m_0, v_0)$
$p(v_k)$	$\mathcal{IG}(a_0, b_0)$	$\mathcal{IG}(a_0, b_0)$	$\mathcal{IG}(a_0, b_0)$	$\mathcal{IG}(a_0, b_0)$
$p(\boldsymbol{\alpha})$	$\mathcal{D}(\alpha_0, \cdots, \alpha_0)$	$\mathcal{D}(\alpha_0, \cdots, \alpha_0)$	$\mathcal{D}(\alpha_0, \cdots, \alpha_0)$	$\mathcal{D}(\alpha_0, \cdots, \alpha_0)$
$p(\theta_e)$	$\mathcal{G}(a_{\epsilon_0}, b_{\epsilon_0})$	$\mathcal{G}(a_{\epsilon_0}, b_{\epsilon_0})$	$\mathcal{G}(a_{\epsilon_0}, b_{\epsilon_0})$	$\mathcal{G}(a_{\epsilon_0}, b_{\epsilon_0})$
$q(\boldsymbol{f}\|\boldsymbol{z})$	$\prod_{\boldsymbol{r}} \mathcal{N}(\hat{\mu}_z(\boldsymbol{r}), \hat{v}_z(\boldsymbol{r}))$	$\prod_{\boldsymbol{r}} \mathcal{N}(\hat{\mu}_z(\boldsymbol{r}), \hat{v}_z(\boldsymbol{r}))$	$\prod_{\boldsymbol{r}} \mathcal{N}(m_z(\boldsymbol{r}), v_z(\boldsymbol{r}))$	$\prod_{\boldsymbol{r}} \mathcal{N}(\hat{\mu}_z(\boldsymbol{r}), \hat{v}_z(\boldsymbol{r}))$
$q(\boldsymbol{z})$	$\prod_{\boldsymbol{r}} \hat{\alpha}_z(\boldsymbol{r}) = \prod_k \hat{\alpha}_k^{n_k}$	$\prod_{\boldsymbol{r}} \hat{\alpha}_z(\boldsymbol{r}) = \prod_k \hat{\alpha}_k^{n_k}$	$\prod_{\boldsymbol{r}} q(z(\boldsymbol{r})\|\bar{z}(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r}))$	$\prod_{\boldsymbol{r}} q(z(\boldsymbol{r})\|\bar{z}(\boldsymbol{r}'), \boldsymbol{r}' \in \mathcal{V}(\boldsymbol{r}))$
$q(m_k)$	$\mathcal{N}(\hat{m}_k, \hat{v}_k)$	$\mathcal{N}(\hat{m}_k, \hat{v}_k)$	$\mathcal{N}(\hat{m}_k, \hat{v}_k)$	$\mathcal{N}(\hat{m}_k, \hat{v}_k)$
$q(v_k)$	$\mathcal{IG}(\hat{a}_k, \hat{b}_k)$	$\mathcal{IG}(\hat{a}_k, \hat{b}_k)$	$\mathcal{IG}(\hat{a}_k, \hat{b}_k)$	$\mathcal{IG}(\hat{a}_k, \hat{b}_k)$
$q(\boldsymbol{\alpha})$	$\mathcal{D}(\hat{\alpha}_1, \cdots, \hat{\alpha}_K)$	$\mathcal{D}(\hat{\alpha}_1, \cdots, \hat{\alpha}_K)$	$\mathcal{D}(\hat{\alpha}_1, \cdots, \hat{\alpha}_K)$	$\mathcal{D}(\hat{\alpha}_1, \cdots, \hat{\alpha}_K)$
$q(\theta_e)$	$\mathcal{G}(\hat{a}_{\epsilon_0}, \hat{b}_{\epsilon_0})$	$\mathcal{G}(\hat{a}_{\epsilon_0}, \hat{b}_{\epsilon_0})$	$\mathcal{G}(\hat{a}_{\epsilon_0}, \hat{b}_{\epsilon_0})$	$\mathcal{G}(\hat{a}_{\epsilon_0}, \hat{b}_{\epsilon_0})$

TAB. 1 – Les lois *a priori* et les lois séparables approchantes pour les quatre modèles proposés.

6 Résultats et discussions

Nous avons utilisé cette approche dans plusieur domaines de problèmes inverses : i) restauration d'image [53, 42], ii) reconstruction d'image en tomographie X [54, 55], et iii) séparation de sources et segmentation des images hyperspectrales [40]. Nous sommes aussi en train de mettre en oeuvre ces algorithmes pour le cas 3D de la tomographie X ainsi qu'au cas de l'imagerie microondes.

Dans tous ces applications, nous avons implémenté à la fois des algorithmes MCMC (échantillonneurs de Gibbs) et l'approche variationnelle bayésienne (VB) développée dans cet article. Nous avons ainsi pu comparé les résultats obtenus par ces deux méthodes. D'une manière générale, les principales conclusions de ces expérimentations et comparaisons sont : i) la qualité des résultats obtenus sont pratiquement similaires, et ii) le principal avantage de l'approche VB est dans le gain en temps de calcul qui dépend bien sure du contexte et de l'applications.

Un autre avantage important que l'on peut mentionner est l'existance d'un critère (l'énergie libre, équation 10) que l'on peut utiliser : i) comme critère d'arrêt pour l'algorithme et ii) comme un critère de choix de modèle. En effet, comme nous l'avons vu, grâce à la relation 9, minimiser $\mathrm{KL}(q : p)$ est équivalent à maximiser $\mathcal{F}(q)$ et sa valeur optimale est un bon indicateur pour $\ln p(\boldsymbol{g}|\mathcal{M})$. Ainsi, les valeurs relatives de $\mathcal{F}(q)$ au cours des itérations de l'algorithme peuvent être utilisées comme un critère d'arrêt et sa valeur optimale atteint pour un modèle $\mathcal{M}_1$ peut être comparée à sa valeur optimale atteint pour un autre modèle $\mathcal{M}_2$ comme un critère de préférence entre les deux modèles.

7 Conclusion

L'approche variationnelle de l'approximation d'une loi par des lois séparables est appliquée au cas de l'estimation non supervisée des inconnues et des hyperparamètres dans des problèmes inverses de restauration d'image (déconvolution simple ou aveugle) avec des modélisations *a priori* gaussiennes, gaussiennes généralisées, mélange de gaussiennes indépendantes ou mélange de Gauss-Markov avec champs cachés des étiquettes indépendantes ou markovien (Potts).

Dans ce papier, nous avons décrit d'abord le principe de l'approximation d'une loi et

ensuite proposé des approximations appropriées pour des lois *a posteriori* conjointes que l'on trouve dans le cas des problèmes inverses en général et en restauration d'images en particulier. Cependant, la mise en oeuvre effective de ces méthodes est en cours et les résultats de simulation et évaluation des performances de ces méthodes seront communiqués dans un future proche.

Les détails de ces relations accompagnés des résultats de simulation qui sont disponible sous forme d'un rapport [53, 42] seront communiqués dans un autre papier en préparation dans un futur proche.

8 Remerciment

L'author souhaite remercier Jean-François Berchet et Guy Demoment pour les discussions fructueuses et la relecture de la première version de ce papier, H. Ayasso et S. Fekih pour l'implémentation de ces algorithmes en restauration d'image et en tomographie X, N. Bali pour l'implémentation de ces algorithmes en séparation de sources et en imagerie hyperspectrale.

Références

[1] J. Rustagi, *Variational methods in statistics*. New York : Academic Press, 1976.

[2] Z. Ghahramani and M. Jordan, "Factorial Hidden Markov Models," *Machine Learning*, no. 29, pp. 245–273, 1997.

[3] W. Penny and S. Roberts, "Bayesian neural networks for classification : how useful is the evidence framework ?," *Neural Networks*, vol. 12, pp. 877–892, 1998.

[4] S. Roberts, D. Husmeier, W. Penny, and I. Rezek, "Bayesian approaches to gaussian mixture modelling," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 20, no. 11, pp. 1133–1142, 1998.

[5] H. Attias, "Independent factor analysis," *Neural Computation*, vol. 11, no. 4, pp. 803–851, 1999.

[6] M. Jordan, Z. Ghahramani, T. Jaakkola, , and L. Saul, "An introduction to variational methods for graphical models," *Machine Learning*, vol. 37, pp. 183–233, 2006.

[7] W. Penny and S. Roberts, "Dynamic models for nonstationary signal segmentation," *Computers and Biomedical Research*, vol. 32, no. 6, pp. 483–502, 1999.

[8] H. Attias, "A variational Bayesian framework for graphical models.," in *Advances in Neural Information Processing Systems* (S. Solla, T. K. Leen, and K. L. Muller, eds.), vol. 12, pp. 209–215, MIT Press, 2000.

[9] T. Jaakkola, "Tutorial on variational approximation methods," in *Advanced mean field methods : theory and practice.* (M. Opper and D. Saad, eds.), (Cambridge, Massachusetts), pp. 129–159, 2000.

[10] J. Miskin, *Ensemble Learning for Independent Component Analysis.* Thèse de doctorat, Cambridge, 2000, `http ://www.inference.phy.cam.ac.uk/jwm1003/`.

[11] J. W. Miskin and D. J. C. MacKay, "Application of ensemble learning to infra-red imaging," in *Proceedings of the Second International Workshop on Independent Component Analysis and Blind Signal Separation*, pp. 399–404, 2000.

[12] J. W. Miskin and D. J. C. MacKay, "Ensemble learning for blind source separation," in *ICA : Principles and Practice* (S. Roberts and R. Everson, eds.), Cambridge : Cambridge University Press, 2001.

[13] W. Penny and S. Roberts, "Bayesian multivariate autoregresive models with structured priors," *IEE Proceedings on Vision, Image and Signal Processing*, vol. 149, no. 1, pp. 33–41, 2002.

[14] S. Roberts and W. Penny, "Variational bayes for generalised autoregressive models," *IEEE Transactions on Signal Processing*, vol. 50, no. 9, pp. 2245–2257, 2002.

[15] M. Cassidy and W. Penny, "Bayesian nonstationary autogregressive models for biomedical signal analysis," *IEEE Transactions on Biomedical Engineering*, vol. 49, no. 10, pp. 1142–1152, 2002.

[16] W. Penny and K. Friston, "Mixtures of general linear models for functional neuroimaging," *IEEE Transactions on Medical Imaging*, vol. 22, no. 4, pp. 504–514, 2003.

[17] W. Penny, S. Kiebel, and K. Friston, "Variational Bayesian inference for fmri time series," *NeuroImage*, vol. 19, no. 3, pp. 727–741, 2003.

[18] R. A. Choudrey and S. Roberts, "Variational bayesian mixture of independent component analysers for finding self-similar areas in images," in *Proc. 4th International Symposium on Independent Component Analysis and Blind Signal Separation (ICA2003)*, (Nara, Japan), pp. 107–112, April 2003.

[19] R. Choudrey and S. Roberts, "Variational Mixture of Bayesian Independent Component Analysers," *Neural Computation*, vol. 15, no. 1, 2003.

[20] W. Penny, R. Everson, and S. Roberts, "Hidden markov independent component analysis," in *Advances in Independent Component Analysis* (M. Giroliami, ed.), Springer, 2000.

[21] D. M. Blei and M. I. Jordan, "Variational methods for the dirichlet process," in *ICML*, 2004.

[22] N. Nasios and A. Bors, "A variational approach for Bayesian blind image deconvolution," *IEEE Transactions on Signal Processing*, vol. 52, no. 8, pp. 2222–2233, 2004.

[23] C. Archambeau, T. Butz, V. Popovici, M. Verleysen, and J. Thiran, "Supervised nonparametric information theoretic classification," in *Proceedings of the 17th International Conference on Pattern Recognition*, vol. 3, pp. 414–417, IEEE, August 2004.

[24] M. Woolrich, E. Timothy, F. Christian, and S. Smith, "Mixture models with adaptive spatial regularization for segmentation with an application to fmri data," *IEEE Trans. on Medical Imaging*, vol. 24, pp. 1–11, January 2005.

[25] D. M. Blei and M. I. Jordan, "Variational methods for the dirichlet process," *Journal Version (TODO : which ?)*, 2006.

[26] M. Beal and Z. Ghahramani, "Variational Bayesian learning of directed graphical models with hidden variables," *Bayesian Statistics*, vol. 1, pp. 793–832, 2006.

[27] H. Kim and Z. Ghahramani, "Bayesian gaussian process classification with the em-ep algorithm," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 28, no. 12, pp. 1948–1959, 2006.

[28] B. Wang and D. Titterington, "Convergence properties of a general algorithm for calculating variational bayesian estimates for a normal mixture model," *Bayesian Analysis*, vol. 1, pp. 625–650, 2006.

[29] K. Watanabe and S. Watanabe, "Stochastic complexities of gaussian mixtures in variational bayesian approximation," *Journal of Machine Learning Research*, pp. 625–644, April 2006.

[30] N. Nasios and A. Bors, "Variational learning for gaussian mixture models," *IEEE Transactions on Systems, Man and Cybernetics, Part B*, vol. 36, no. 4, pp. 849–862, 2006.

[31] K. Friston, J. Mattout, N. Trujillo-Barreto, J. Ashburner, and W. Penny, "Variational free energy and the laplace approximation," *Neuroimage*, no. 2006.08.035, 2006. Available Online.

[32] W. Penny, S. Kiebel, and K. Friston, "Variational bayes," in *Statistical Parametric Mapping : The analysis of functional brain images* (K. Friston, J. Ashburner, S. Kiebel, T. Nichols, and W. Penny, eds.), Elsevier, London, 2006.

[33] Z. Ghahramani, T. Griffiths, and P. Sollich, "Bayesian nonparametric latent feature models," *Bayesian Statistics*, vol. 8, 2007.

[34] C. McGrory and D. Titterington, "Variational approximations in Bayesian model selection for finite mixture distributions," *Computational Statistics and Data Analysis*, vol. 51, no. 11, pp. 5352–5367, 2007.

[35] F. Forbes and F. Gersende, "Combining monte carlo and mean-field-like methods for inference in hidden markov random fields," *IEEE Trans. on Image Processing*, vol. 16, pp. 824–835, March 2007.

[36] M. Ichir and A. Mohammad-Djafari, "A mean field approximation approach to blind source separation with lp priors," in *Eusipco 2005, Antalya, Turkey, September 2005*, Eusipco 2005, Antalya, Turkey, September 2005, September 2005.

[37] M. Ichir and A. Mohammad-Djafari, "Hidden markov models for wavelet image separation and denoising," in *Proc. IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP '05)*, vol. 5, pp. v/225–v/228, 18–23 March 2005.

[38] H. Snoussi and A. Mohammad-Djafari, "Estimation of structured gaussian mixtures : The inverse em algorithm," *IEEE Trans. on Signal Processing*, vol. 55, pp. 3185–3191, July 2007.

[39] N. Bali and A. Mohammad-Djafari, "Mean Field Approximation for BSS of images with compound hierarchical Gauss-Markov-Potts model," in *MaxEnt05,San José CA,US*, American Institute of Physics (AIP), August 2005.

[40] N. Bali and A. Mohammad-Djafari, "Bayesian approach with hidden markov modeling and mean field approximation for hyperspectral data analysis," *IEEE Trans. on Image Processing*, vol. 17, pp. 217–225, Feb. 2008.

[41] A. Mohammad-Djafari, "Approche variationnelle pour le calcul bayésien dans les problèmes inverses en imagerie," in *GRETSI*, Troyes, France, September 2007.

[42] H. Ayasso and A. Mohammad-Djafari, "Variational bayes with gauss-markov-potts prior models for joint image restoration and segmentation," Visapp Proceedings, (Funchal, Madaira, Portugal), Int. Conf. on Computer Vision and Applications, 2008.

[43] A. Mohammad-Djafari, "Gauss-markov-potts priors for images in computer tomography resulting to joint optimal reconstruction and segmentation," *International Journal of Tomography & Statistics*, vol. 11, no. W09, pp. 76–92, 2008.

[44] R. Molina, A. K. Katsaggelos, and J. Mateos, "Bayesian and regularization methods for hyperparameter estimation in image restoration," *IEEE Transactions on Image Processing*, vol. 8, pp. 231–246, February 1999.

[45] A. Likas and N. Galatsanos, "A variational approach for Bayesian blind image deconvolution," *IEEE Trans. on Signal Processing*, vol. 52, pp. 2222–2233, August 2004.

[46] K. Blekas, A. Likas, N. Galatsanos, and I. Lagaris, "A spatially-constrained mixture model for image segmentation," *IEEE Trans. on Signal Processing*, vol. 16, pp. 494–498, March 2005.

[47] A. Mohammad-Djafari and L. Robillard, "Hierarchical Markovian models for 3D computed tomography in non destructive testing applications," in *EUSIPCO 2006*, EUSIPCO 2006, September 4-8, Florence, Italy, September 2006.

[48] M. Patriksson, *Nonlinear programming and variational inequality problems. A unified approach.* Applied Optimization, Dordrecht, The Netherlands : Kluwer Academic Publishers, May 1999.

[49] R. Choudrey, W. Penny, and S. Roberts, "An ensemble learning approach to independent component analysis," in *IEEE Workshop on Neural Networks for Signal Processing, Sydney Australia*, 2000.

[50] W. Penny and S. Roberts, "Variational bayes for non-gaussian autoregressive models," in *IEEE Workshop on Neural Networks for Signal Processing, Sydney Australia*, 2000.

[51] R. Choudrey and S. Roberts, "Variational Bayesian Mixture of Independent Component Analysers for Finding Self-Similar Areas in Images," in *ICA, NARA, JAPAN*, April 2003.

[52] B. R. Hunt, "A matrix theory proof of the discrete convolution theorem," *IEEE Transactions on Automatic and Control*, vol. AC-19, pp. 285–288, 1971.

[53] H. Ayasso and A. Mohammad-Djafari, "Approche bayésienne variationnelle pour les problèmes inverses. application en tomographie microonde," tech. rep., Rapport de stage Master ATS, Univ Paris Sud, L2S, SUPELEC, 2007.

[54] H. Ayasso, S. Fekih-Salem, and A. Mohammad-Djafari, "Variational bayes approach for tomographic reconstruction," in *Proceedings of the 28th International Workshop on Bayesian*

Inference and Maximum Entropy Methods in Science and Engineering, MaxEnt, vol. 1073, (Boraceia, Sao Paulo (Brazil)), pp. 243–251, AIP, November 2008.

[55] H. Ayasso and A. Mohammad-Djafari, "Joint image restoration and segmentation using gauss-markov-potts prior models and variational bayesian computation," *Submitted to IEEE Image Processing*, Febuary, 2009.